

Classification grande échelle de surfaces d'eau par lidar aéroporté.

Nicolas DAVID¹, Julien SMEECKAERT², Clément MALLET¹

¹IGN/SR, MATIS Université Paris-Est – 73 avenue de Paris, 94160 Saint-Mandé, France

²SHOM – 29228 Brest Cedex 02, France

prenom.nom@ign.fr

Résumé – La gestion des zones littorales utilise aujourd'hui de plus en plus de Modèles Numérique de Terrain (MNT) issus de données laser aéroportées. Afin d'obtenir des MNT fiables sur ces zones il est nécessaire d'extraire les surfaces d'eau des nuages de points. Pour cela, cet article propose une méthode automatique, robuste et générique de classification supervisée fondée sur les séparateurs à vaste marge (SVM). Premièrement, un jeu de descripteurs utilisant seulement les coordonnées 3D des points laser et l'information de ligne de vol est élaboré. Puis des zones d'apprentissage SVM fiables sont sélectionnées automatiquement par une croissance de régions. Enfin, les erreurs de classification pixellaires sont filtrées par une relaxation probabiliste utilisant les scores de classification SVM. Les résultats montrent que d'importants chantiers lasers (> 100 M pts) de faible densité (2-3 pts/m²) sont classés avec une forte précision globale (>95%) tout en préservant les objets de petites tailles ayant une importance topographique (ponts, canaux, rochers).

Abstract – There is today a considerable use of accurate Digital Terrain Models (DTM) generated from topographic lidar scanning for coastal areas management. In such areas, for more reliable DTM generation, additionally to process common ground filtering workflow, water areas have also to be extracted from raw point cloud data. For that purpose, this paper presents an automatic, efficient, and versatile classification workflow based on Support Vector Machines (SVM). First, a set of features, based only on 3D coordinates and flightline information, is defined. Then, a region growing strategy automatically selects small but well-targeted areas to retrieve training pixels. Finally, SVM label probabilities are merged with spatial constraints during a probabilistic relaxation step in order to remove pixel-wise misclassification. Results show that survey of millions of points, with low point densities (2-3 pts/m²) are labelled with high accuracy (>95%) and that small features of interest are still well classified (bridges, rocks, canals)

1 Introduction

1.1 Motivation

Les zones littorales sont d'importantes zones à enjeux de part leur densité de population et leur forte exposition à de nombreux risques naturels : tempêtes, marées noires, effets du réchauffement climatique. Malgré cela il existe relativement peu de données topographiques de référence permettant une gestion efficace des politiques publiques de ces zones. D'une part les méthodes de surveillance par levé terrestre peuvent difficilement être étendues à une échelle nationale. D'autre part les données de références existantes souffrent à la fois d'un manque de précision géométrique et d'une gestion différenciée entre domaines terrestre et maritime.

Pour ces raisons, l'utilisation d'images optique ou radar sert depuis longtemps à effectuer une surveillance rapide à large échelle de l'évolution des zones littorales et à identifier les zones à fort risque. Mais ces techniques ne permettent pas d'obtenir de représentation assez précise de la surface terrestre (appelée MNT : *Modèle Numérique de Terrain*). L'évolution récente de la technique de télédétection lidar aéroporté répond désormais à ce besoin d'obtention de MNT précis à échelle régionale (>100 km²) : cette technique délivre directement des points 3D très précis géométriquement mais échantillonnant

irrégulièrement la surface terrestre [1]. Des pays comme les Pays-bas et le Canada utilisent déjà, à une échelle nationale, de tels MNT laser comme outil de décision pour des politiques de prévention de risques [2].

Des acquisitions systématiques par lidar des zones côtières et fluviales ont aussi lieu en France depuis 2007. L'objectif est de constituer une représentation unique terre/mer des terrains acquis et de cartographier plus finement les zones fluviales, notamment pour pouvoir étudier plus finement le risque inondation. Afin d'obtenir des MNT précis géométriquement, les points 3D correspondant au sol, et non à l'eau doivent être extraits. Ce processus est à l'heure actuelle semi-automatique, peu robuste et fastidieux.

Le but de cet article est de proposer une méthodologie de classification terre/mer de données lidar aéroporté adaptée à un contexte d'automatisation de chaîne de production. Celle-ci a donc pour objectif d'être efficace à grande échelle et adaptée aux nombreux paysages maritimes et fluviaux français.

1.2 Etat de l'art

La cartographie de zones d'eau à partir de données laser aéroporté consiste aujourd'hui essentiellement en l'extraction de l'interface terre-eau à partir de MNT précis (seuil à une altitude égale à 0 m) [3]. Toutefois, peu d'auteurs se penchent en

amont sur la classification des nuages de points 3D. Ils s'appuient sur des descripteurs 3D simples, spécifiques à un type de paysage, souvent avec peu de relief [4]. Ces attributs sont souvent couplés, dans des classificateurs non supervisés, à d'autres informations, comme la forme du signal lidar ou la radiométrie d'images aériennes [5] mais les auteurs notent des taux importants de confusion entre surfaces d'eau et zones terrestres de géométrie et de radiométrie identiques (routes en asphalte, champs etc.). Une solution plus efficace a été proposée récemment dans [6], avec l'utilisation de Conditional Random Fields et d'informations contextuelles. Cependant, les temps d'apprentissage et d'inférence sont rhébitoires dans le cas de classification à grande échelle.

La méthode proposée dans cet article apporte plusieurs contributions à l'existant :

- une stratégie de classification rapide et compatible avec le traitement de large jeux de données.
- une approche entièrement automatique et ne nécessitant pas d'ajuster les paramètres en fonction du paysage.
- une procédure générique : adaptée aux différents types de paysages (falaises, dunes, ports etc.) et aux différents types de données laser (ne demande en entrée que les coordonnées 3D et les informations de ligne de vol).

2 Méthodologie

L'approche proposée consiste en une classification pixellaire supervisée par Séparateurs à Vaste Marge (SVM) en *eau* et *terre*. Les nuages de points 3D sont en effet interpolés sur une grille régulière au pas de 1m, correspondant à la résolution spatiale des données lidar, afin d'optimiser le temps de traitement et d'obtenir des relations de voisinages simples entre mesures. Les SVM sont choisis pour leurs capacités à classer de manière rapide et à généraliser depuis un ensemble d'apprentissage réduit des données de grande dimension. Les données en entrée sont ici des descripteurs géométriques, directement calculés en 3D à partir des données brutes, puis reprojétés sur la grille 2D.

2.1 Descripteurs spatiaux

De multiples attributs géométriques décrivant la forme locale d'un nuage de points existent. Nous en proposons cinq adaptés à notre contexte, afin de décrire du mieux possible les comportements hétérogènes des classes *eau* et *terre*. Afin de rester générique il a été choisi de ne pas utiliser d'attributs basés sur des informations d'intensité laser ou d'image RVB. Chacun des cinq descripteurs est interpolé en géométrie 2D régulière par moyenne des descripteurs 3D contenus dans chaque pixel. Les attributs choisis peuvent alors être regroupés selon trois familles :

(1) **Altitude** : Les étendues d'eau peuvent être caractérisées comme occupant toujours un minimum local d'altitude. De plus dans le cas de zones littorales ce minimum local devient généralement un minimum global. L'altitude au dessus du géoïde est donc sélectionnée comme attribut (essentiellement pertinent en zone côtière).

(2) **Densité** : Les surfaces d'eau possèdent d'importantes propriétés d'absorption du signal laser émis ainsi qu'une forte specularité. La densité des données est alors liée à l'angle d'incidence du faisceau laser avec la surface. Sur la mer, on observe plus de mesures à la verticale de l'avion qu'à des angles supérieurs à 10° . Deux attributs ont été définis pour refléter ces propriétés physiques : la densité majoritaire D_m et un ratio de densité D_r .

$$D_m = \max_{\text{ligne1}, \text{ligne2}} \{D_{\text{ligne1}}, D_{\text{ligne2}}\} = D_{\max}. \quad (1)$$

$$D_r = \frac{D_{\max} - D_{\min}}{D_{\max}} \in [0, 1]. \quad (2)$$

D_m est une densité locale ne prenant en compte que la ligne de vol ayant la plus forte densité : cet attribut est donc moins sensible au recouvrement entre bande qu'une densité calculée sur l'ensemble des données. L'attribut D_r permet de prendre en compte le caractère spéculaire des surfaces d'eau.

(3) **Géométrie** : Sur terre, les données lidar permettent une description complète de la topographie et des objets présents (végétation, bâtiments). Les nuages de points 3D offrent une représentation planimétrique assez homogène mais avec de hautes fréquences et une dispersion altimétrique dépendant des objets peuplant le paysage. Sur mer, les données forment une surface quasi plane. Deux attributs de forme sont donc calculés à partir de la matrice de variance-covariance obtenue pour chaque point 3D. Soit λ_1, λ_2 , and λ_3 les valeurs propres de la matrice de covariance rangées par ordre décroissant. Le premier attribut de forme utilisé est λ_3 . En effet $\lambda_3 \simeq 0$ pour les zones planaires et $\lambda_3 > 0$ sur les zones de sols de part sa rugosité et $\lambda_3 \gg 0$ pour tout relief important. Le deuxième attribut de forme est le *scatter*, défini comme $S = \lambda_3/\lambda_1 \in [0, 1]$.

2.2 Apprentissage

L'élaboration de l'ensemble d'apprentissage est effectuée de manière active et automatique. On sélectionne tout d'abord des pixels purs pour les deux classes : les valeurs extrêmes de planarité et de dispersion altimétrique fournissent pour cela des échantillons fiables respectivement des classes *eau* et *terre*. Les fortes valeurs de *scatter* correspondent aux zones de bâti ou de végétation, tandis que les valeurs les plus faibles de λ_3 correspondent aux zones les plus plates, i.e., essentiellement des surfaces d'eau. Des seuils pour ces deux types de graines sont obtenus de façon automatique à partir des fonctions de répartition de ces deux attributs (calculées avec 500.000 pixels). Les pixels pur d'eau (terre) sont alors ceux ayant une valeur de λ_3 (*scatter*) plus petite (grande) que celle du premier (dernier) point d'inflexion de la courbe correspondante.

Ces pixels purs ne sont toutefois pas performants pour une classification par SVM mais servent à affiner spatialement la recherche d'échantillons représentatifs de la frontière entre les deux classes. Pour cela, on introduit la connaissance approximative du trait de côte (interface eau/terre). Une zone tampon est construite à partir des pixels appartenant au trait de côte. Cette dernière est dilatée jusqu'à ce que 40% des pixels purs

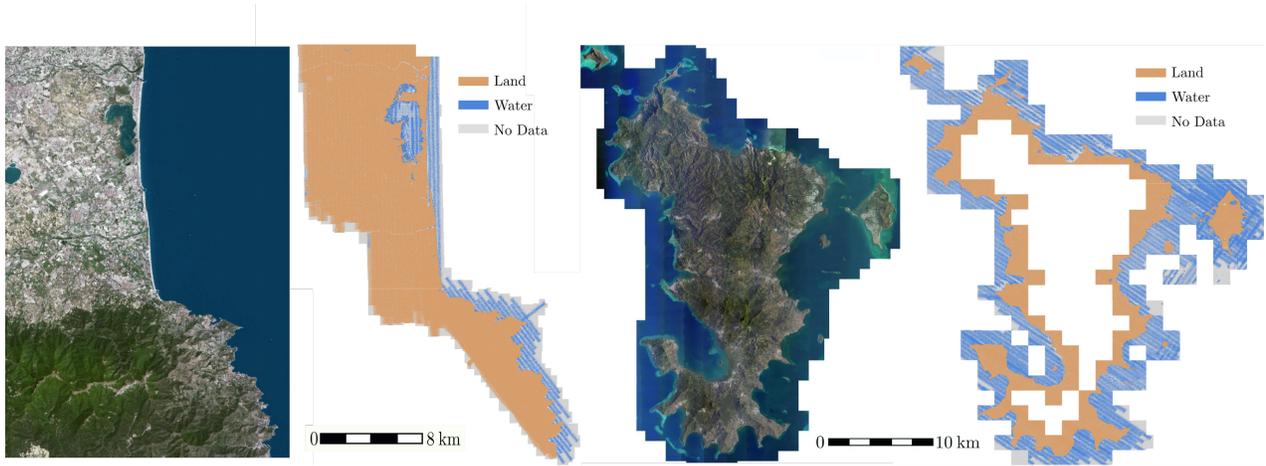


FIGURE 1 – Résultats sur les deux zones tests de (a) Perpignan et (b) Mayotte (droite) L’orthoimage ©IGN de chaque région est présentée ainsi que la classification 2D obtenue (Bleu : Eau – Orange : Terre – Blanc : Pas de données).

de chaque classe soit inclus dans la zone tampon. Les zones connexes sont ensuite retrouvées par une croissance de régions et étiquetées *eau* et *terre* en fonction des pixels purs majoritaires. Les échantillons finaux des classes *eau* et *terre* sont alors définis par tirage aléatoire en gardant 1% des pixels dans les zones étiquetées *eau* et *terre* mais proche des marges SVM. Enfin, pour gagner du temps de calcul, cette procédure d’apprentissage n’est effectuée aléatoirement que sur 3% des dalles du chantiers en ajoutant une contrainte de distance (> 10 km) entre deux zones d’apprentissage.

2.3 Classification eau/terre

Un classifieur SVM est initialisé par apprentissage actif et se fonde sur les descripteurs 2D. Un noyau gaussien est choisi et les deux hyper-paramètres sont optimisés via une stratégie de recherche par grille. Comme la classification SVM est de type pixellaire les résultats peuvent être bruités. Une solution simple pour palier cela est d’effectuer un filtrage *a posteriori* des résultats SVM [8]. Pour chaque pixel, une nouvelle étiquette est alors calculée par pondération des étiquettes de son voisinage. Une telle solution à l’avantage d’améliorer les résultats de classification sans introduire un surcoût de temps de calcul trop important. La méthode de filtrage choisie repose sur une relaxation probabiliste [9] ce qui permet de tenir compte des probabilités d’appartenance disponibles en sortie de la classification SVM. Pour chaque pixel i on calcule une énergie d’appartenance à l’étiquette l selon la formule :

$$E_l(i) = \sum_{j \in V(i)} G_\sigma(\|i - j\|) \cdot E_l(j) \cdot M_{i,j}[l, l_j]. \quad (3)$$

Où $G_\sigma(\|i - j\|)$ est le poids du pixel j avec G_σ une distribution gaussienne centrée de variance σ^2 ($\sigma=1$ dans nos tests), $V(i)$ est le voisinage utilisé (ici une fenêtre 5×5), et M représente la matrice de compatibilité entre le pixel i d’étiquette l et le pixel j d’étiquette l_j . Les valeurs utilisées pour M sont :

$$M = \begin{pmatrix} 0,8 & 0,2 \\ 0,2 & 0,8 \end{pmatrix}. \quad (4)$$

La matrice M encode les *a priori*, dans un voisinage donné, sur les corrélations entre probabilités d’appartenance à une étiquette. Les coefficients de M vérifient en tant que probabilités conditionnelles $0 \leq M_{i,j}[l, l_j] \leq 1$, et $\sum_l M_{i,j}[l, l_j] = 1$. Leur choix a été fait de manière empirique.

3 Données et résultats

Deux zones d’études, Perpignan et Mayotte, ont été retenues pour la validation de la méthode proposée. Toutes deux ont été acquises avec un lidar aéroporté fournissant une densité de points entre 2 et 4 pts/m². Chacune des zones comporte plus de 100 millions de points et couvre plusieurs centaines de km² (Tableau 1). Elles incluent un grand nombre de paysages côtiers et fluviaux complexes (ports, falaises, plages anthropiques et naturelles, estuaires, marais, lacs, mangroves) qui ont également permis de valider à plus fine échelle la qualité de la méthode (Figure 1).

Malgré des occupations du sol très hétérogènes (milieux méditerranéens et tropicaux avec plusieurs centres urbains), les résultats sont très satisfaisants, avec une précision globale supérieure à 96%. Cela valide le choix des descripteurs géométriques proposés ainsi que la création de l’ensemble d’apprentissage. La relaxation probabiliste offre une régularisation efficace des résultats. Les zones d’eau sont les mieux discriminées ($>98\%$) car leur comportement est le plus simple à modéliser. Des erreurs ponctuelles de classification restent mais ne perturbent pas la délimitation des zones d’eau et terre. De

| Chantier (# points) | Avant SVM | Après relaxation | % pixels d’apprentissage |
|----------------------------|-----------|------------------|-----------------------------|
| | OA (%) | OA (%) | |
| Perpignan (831.814.063) | 97,47 | 98,27 | 0,14 |
| Mayotte (620.120.967) | 96,55 | 96,59 | 3,65 |

TABLE 1 – Précision globale (OA) pour les deux chantiers. plus, on peut noter que les hautes fréquences du paysage (ro-

chers, digues, ponts, bateaux, petites étendues d'eau) sont préservées, ainsi que les transitions fines entre classes (plages de sable avec faible dénivellée et estuaire) (Figure 2). On note aussi que l'utilisation d'un trait de côte approximatif (précision 50 m ne contraint pas la classification et n'est pas sensible aux modifications d'infrastructure côtière (ajout ou modification de digues, jetées etc.)



FIGURE 2 – Résultat d'une dalle en Bretagne. Le trait de côte littoral utilisé est affiché sur l'orthoimage et la classification. (Bleu : Eau – Orange : Terre – Blanc : Pas de données)

Enfin, les attributs 3D choisis offrent un bon compromis entre complexité de calcul et qualité de classification mais ne permettent pas de modéliser des paysages complexes où les deux classes sont mélangées (mangroves) ou lors du survol de zones à forts coefficients de marées (Figure 3).

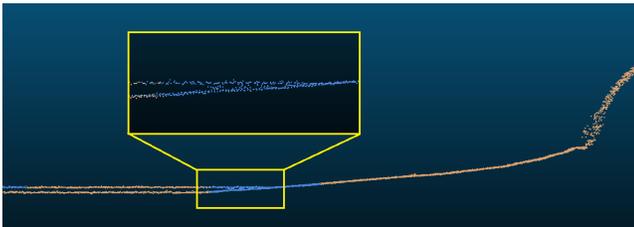


FIGURE 3 – Coupe altimétrique sur une zone à fort coefficient de marée. Mauvaise classification dans la zone nord-ouest de la Figure 2). (Bleu : Eau – Orange : Terre)

Le temps de calcul de l'ensemble de la chaîne de traitement est d'environ 30 minutes pour 1 km² sur un ordinateur simple cœur. Actuellement, un opérateur humain traite en moyenne 20 dalles de 1 km² par jour, soit 7h, contre 192 dalles par jours, soit 24h, pour un ordinateur 4 coeurs. Cela correspond à un gain de temps d'un facteur 10.

4 Conclusion

Nous avons proposé dans cet article une méthode de classification automatique et active des zones d'eau dans des nuages de points 3D lidar. Ce processus est efficace à grande échelle et offre une précision globale de classification élevée. Elle s'applique à de très nombreux paysages maritimes et fluviaux et conserve des objets de petite taille à fort enjeu, tels que les ponts et les digues, malgré de faibles densités de points. Elle peut donc s'avérer utile pour détecter des changements et mettre à jour le trait de côte et des bases de données d'occupation du

sol. Les erreurs de classification restantes peuvent être corrigées par l'ajout de connaissance contextuelle et n'affectent pas la génération finale des Modèles Numériques de Terrain. Afin d'étendre notre méthode à l'ensemble des zones d'eau, rivières, lacs etc. il serait intéressant d'effectuer une étude de sélection des descripteurs présent dans la littérature et de qualifier leur apport selon les différents paysages.

Remerciements : Les auteurs tiennent à remercier Ayméric Godet, Philippe Jolivet (IGN) et Vincent Lamarre (SHOM) pour leur aide dans l'élaboration des jeux test et des vérités terrain.

Références

- [1] C. Mallet, F. Bretar. *Le Lidar Topographique à Retour d'Onde Complète : Etat de l'art*. Traitement du Signal 24(6) : 441-465, 2007.
- [2] S. Pe'eri, B. Long. *Lidar technology applied in coastal studies and management*. Journal of Coastal Research 62(1-5), 2011.
- [3] S. White, Y. Yang. *Utilizing DEMs derived from lidar data to analyze morphologic change in the North Carolina coastline*. Remote Sensing of Environment 85(1), 39-47 2003.
- [4] A. Brzank, C. Heipke, J. Goepfert et U. Soergel. *Aspects of generating precise digital terrain models in the Wadden Sea from lidar and structure line extraction*. Journal of Photogrammetry and Remote Sensing 63(5) :510-528, 2008.
- [5] I.C. Lee, B. Wu et R. Li. *Shoreline extraction from the integration of lidar point cloud data and aerial orthophotos using mean-shift segmentation*. ASPRS Annual Conference, Baltimore, États-Unis, 2009.
- [6] A. Schmidt, F. Rottensteiner et U. Soergel. *Classification of airborne laser scanning data in Wadden Sea areas using Conditional Random Fields*. International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences XXXIX(Part B3) : 161-166, 2012.
- [7] G. Mountrakis, J. Im et C. Ogole. *Support vector machines in remote sensing : A review*. ISPRS : Journal of Photogrammetry and Remote Sensing 66(3) : 247-259, 2011.
- [8] K. Schindler. *An overview and comparison of smooth labeling methods for land-cover classification*. IEEE Transactions on Geoscience and Remote Sensing 50(11) : 4534-4545, 2013.
- [9] P. Gong, P. Howarth. *Performance analyses of probabilistic relaxation methods for land-cover classification*. Remote Sensing of environment 30(1) : 33-42, 1989.
- [10] T. Wu, C.J. Lin, R. Weng *Probability estimates for multi-class classification by pairwise coupling*. Journal of Machine Learning Research 5 : 975-826, 2004.